



Algoritmid ja andmestruktuurid

ja nende keerukus

Marko Kääramees



Miks on vaja algoritme ja andmestruktuure

Leida kiireim tee punktist A punkti B

- Andmestruktuurid

Andmed tuleb kuidagi esitada

- Sõidurajad, võimalikud pöörded, mitmetasandilised teed, ühesuunalised tänavad, liikumiskiiruse erinevus

- Kiire algoritm

- Piiratud arvutusvõimsus
- Suur andmemahut (kõik Euroopa teed-tänavad)
- Arvuti ei vaata kaardile “ülevaalt-alla”
arvutada tuleb andmebaasi kirjetel, mitte graafilisel pildil





Kuidas sorteerida mullitajaid?



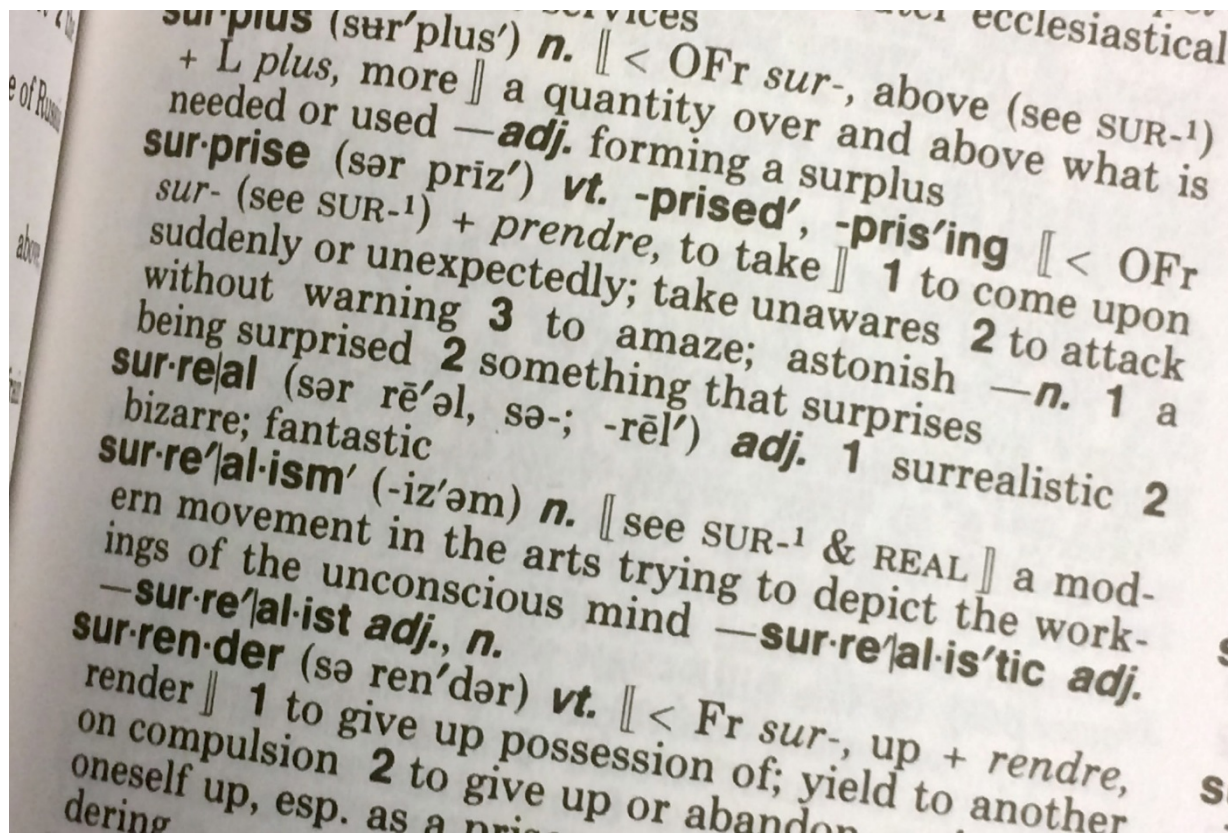
Reeglid:

See mullitaja mida kätte võtad, tuleb panna kaalule
Võidab see, kes kaalub kõige vähem kordi



Miks sorteerida?

- Otsimine põhineb sellel, et andmed on sorteeritud





Selection sort

Korda kuni kõik on sorteeritud

leia minimaalne listi sorteerimata osast

tõsta see listis järgmise sorteerimata kohale



SelectionSort(list):

list : array of items

n : size of list

for i = 1 to n - 1

 min = i

 for j = i+1 to n

 if list[j] < list[min] then

 min = j;

if indexMin != i then

 swap list[min] and list[i]



Mitu võrdlust on vaja?

- List 4 elemendiga
 - Min 4 elemendist – 3 võrdlust
 - Min 3 elemendist – 2 võrdlust
 - Min 2 elemendist – 1 võrdlust
 - Kokku $3+2+1 = 6$ võrdlust
- List 8 elemendiga
 - Kokku $7+6+5+4+3+2+1 = 28$ võrdlust
- Üldjuhul n elemendi korral aritmeetiline jada $n-1$

$$\sum_{i=1}^{n-1} i = \frac{(n-1)(n)}{2}$$

| | | | |
|---|---|---|---|
| 3 | 1 | 4 | 2 |
| 1 | 3 | 4 | 2 |
| 1 | 2 | 4 | 3 |
| 1 | 2 | 3 | 4 |

| n | võrdlusi |
|-----|----------|
| 4 | 6 |
| 8 | 28 |
| 16 | 120 |
| 32 | 496 |



Algoritmide keerukus

Algoritmi keerukus on põhioperatsiooni(de) arvu sõltuvusfunktsioon $K(n)$ sisendi(te) suurusest n .

- *Põhioperatsioon* ei ole üheselt defineeritav
 - Midagi mis on riistvaras tehtav piiratud arvu sammudega
 - aritmeetika tehe, võrdlus, omistus
 - vahel valitakse üks põhioperatsioon ja loetakse selle arvu, näiteks tsüklitingimuse võrdlus
 - mõnikord kasutatakse ka ridade arvu
- *Sisendi suurus* võib olla defineeritud erinevalt
 - Sisendandmete maht (massiivi, faili, andmebaasi suurus)
 - Sisendparameetri väärtus
 - Sisendparameetri suurus (bittide/baitide arv)




Kas õnnestuks sorteerida vähema
arvu võrdlemistega?
Efektiivsemalt?



Jaga ja Valitse strateegia

Divide et Impera

CAESAR



Napoleon





Jaga ja Valitse strateegia

- Jaga
Jaga ülesanne lihtsamateks alamülesanneteks
- Valitse
Lahenda alamülesanded
- Ühenda
Leia lahendus alamülesannete lahenduste kaudu



Merge sort

- 1 Jagame massiivi pooleks
Sorteerime mõlemad väiksemad massiivid
- 2 Ühendame sorteeritud massiivid üheks sorteeritud massiiviks võrreldes omavahel mõlema massiivi väiksemaid elemente
- 3 Jagamise lõpetamistingimuseks on 1 elemendiga massiiv
- 4 Ühe elemendiga massiivi võib lugeda sorteerituks, tagastame sellesama massiivi





Mergesort

```
mergesort (int n, list S[ ]) {  
  if (n>1) {  
    int h=[n/2],    m = n - h;  
    list U[1 ..h], V[1 ..m];  
    copy S[1] through S[h] to U[1] through U[h];  
    copy S[h+1] through S[n] to V[1] through V[m];  
    mergesort(h, U);  
    mergesort(m, V);  
    merge (h, m, U, V, S);  
  }  
}
```

```
merge (int h, int m, list U[ ], list V[ ], list S[ ]) {  
  index i, j, k;  
  i = 1; j = 1; k = 1;  
  while (i <= h && j <= m) {  
    if (U[i] < V[j]) { S[k] = U[i]; i++; }  
    else { S[k] = V[j]; j++; }  
    k++; }  
  if (i>h) copy V[j] through V[m] to S[k] through S[h+m];  
  else copy U[i] through U[h] to S[k] through S[h+m]; }
```



Mitu võrdlust on vaja?

- Tähistame keerukuse funktsiooniga $K(n)$, kus n on sisendlisti elementide arv
- Tuleb sorteerida kaks osalist pikkusega $n/2$, selle jaoks on vaja teha 2 korda $K(n/2)$ võrdlust
- Tuleb kaks sorteeritud osalist kokku panna (*merge*)
 - Tulemus on pikkusega n
 - Iga võrdlusega saame tulemusse 1 elemendi juurde, viimase niisama kokku $n-1$ võrdlust

$$K(n) = 2K(n/2) + (n-1)$$

???



Proovime

- Kui listis on 2 elementi
 - 1 võrdlus
- Kui listis on 4 elementi, siis
 - Osalistide sorteerimised 1+1
 - Merge 3
 - Kokku 5
- Kui listis on 8 elementi, siis
 - Osalistide sorteerimised 5+5
 - Merge 7
 - Kokku 17
- Üldjuhul
$$(n-1)\log(n-1) + \log(n)$$



Mis vahet neil on?

Eestis oli elanikke 1. jaanuar 2017
1315635

- Sorteerime need ära
 - Arvuti protsessor töötab 4 GHz
 - Iga taktiga tehakse üks võrdlus

| Algoritm | võrdlusi | Aega |
|----------------|---------------------|----------------|
| Selection sort | $8.7 \cdot 10^{11}$ | 216s = 3.5 min |
| Merge sort | $8.7 \cdot 10^7$ | 0.007s |



O-notatsioon

- O-notatsioonis esitatakse keerukusfunktsiooni määrav komponent

$$1/2 (n-1) * n \in O(n^2)$$

- Liidetavatest suurima keerukusega funktsioon

$$n^2 - n \in O(n^2)$$

- Konstantseid kordajaid võib ignoreerida

$$1/2 * n^2 \in O(n^2)$$

- Spetsiaalsed keerukusklassid:

logaritmiline: $O(\log n)$

lineaarne: $O(n)$

polünoomiaalne: $O(n^k), k \geq 1$

eksponentsiaalne: $O(a^n), n > 1$





Sorteerimiste keerukused

- Selection sort

$$\sum_{i=1}^{n-1} i = \frac{(n-1)(n)}{2} \in O(n^2)$$

- Merge sort

$$(n-1)\log(n-1) + \log(n) \in O(n \log n)$$

Neid on võimalik määrata ilma katsetamata, algoritmi analüüvides



Quicksort

- 1 Valime ühe elemendi teljeks (pivot)
Sorteerime kõik teljest väiksemad temast vasakule ja suuremad paremale
Sorteerime teljest paremale ja vasakule jääva massiivi
- 2 Ühendame vasaku massiivi, telje ja parema massiivi üksteise järgi
- 3 Jagamise lõpetamistingimuseks on 1 elemendiga massiiv
Ühe elemendiga massiivi võib lugeda sorteerituks, tagastame sellesama massiivi





Erinevad keerukusmõõdud

| n | Võrdlusi min | Võrdlusi max |
|---|--------------|--------------|
| 2 | 1 | 1 |
| 4 | 4 | 6 |
| 8 | 13 | 28 |

- Halvima juhu keerukus $O(n^2)$
- Keskmise juhu keerukus $O(n \log n)$

Mis on *quicksort-i* jaoks halvim sisend?





Edasi?

- Kas saab veel kiiremini?
- Kui kasutada võrdlemist, siis ei saa



Massiiv ja list



Massiiv

- + kiire pöördumine
- piiratud maht
- aeglane *add/delete*

List

- aeglane pöördumine
- + piiramatu maht
- + kiire *add/delete*




Lingitud listi rakendus - Radix sort


Numbers to be sorted

| | | | | | | | | | |
|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 239 | 234 | 879 | 878 | 123 | 358 | 416 | 317 | 137 | 225 |
|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|


Numbers distributed
by rightmost digit



Numbers distributed
by second digit
from right



Numbers distributed
by third digit
from right





Radixsort

```
void radixsort (node_pointer& masterlist,  
                int numdigits)  
{  
    index i;  
    node_pointer list[0..9];  
  
    for (i = 1; i <= numdigits; i++) {  
        distribute(i);  
        coalesce;  
    }  
}
```



Radixsort

```
void distribute (index i)                                // i is index of current
{                                                         // digit being inspected.
    index j;
    node_pointer p;

    for (j = 0; j <= 9; j++)                          // Empty current piles.
        list[j] = NULL;

    p = masterlist;                                     // Traverse masterlist.
    while (p != NULL) {
        j = value of ith digit (from the right) in p -> key;
        link p to the end of list[j];
        p = p -> link;
    }
}
```




Radixsort

```
void coalesce ()  
{  
    index j;  
  
    masterlist = NULL;                                // Empty masterlist.  
    for (j = 0; j <= 9; j++)  
        link the nodes in list[j] to the end of masterlist;  
}
```



Radixsort keerukus

- Põhioperatsiooniks *pointeri* omistamine
 - *distribute* n
 - *coalesce* 10
- Radixsort põhitsükkel
 - sõltub kohtade arvust $numdigits$

$$T(n) = numdigits (n + 10) \in \Theta(numdigits * n)$$

$n = numdigits$

$$T(n) \in \Theta(n^2)$$

kõik sorteeritavad on erinevad


$$T(n) \in \Omega(n \log n)$$



Paralleelne Mergesort

ALGORITHM: mergesort(A)

```
1 if (|A| = 1) then return A
2 else
3   in parallel do
4     L := mergesort(A[0..|A|/2])
5     R := mergesort(A[|A|/2..|A|])
6   return merge(L, R)
```



Keerukus $O(n)$, vajab $O(n)$ protsessorit

Odd-Even Parallel Mergesort võib sorteerida
keerukusega $O((\log n)^2)$, vajab $O(n)$ protsessorit



Kokkuvõtteks

- **Tasub mõelda**
probleemi lahendades tasub leida efektiivne algoritm
- **Tasub analüüsida**
Keerukust saab analüüsida algoritmi pealt ilma aega mõõtmata
- **Vee all võivad olla karid**
Alati ei lange keskmine ja halvima juhu keerukus ei pruugi kokku langeda
- **Jõuga ja nõuga võib saada rohkem**
Ülesande ümberdefineerimine ja paralleelsus aitavad